

Türkiye’de Enflasyon Öngörüsünde Klasik Zaman Serisi ve Makine Öğrenmesi Modellerinin Performansı

The Performance of Classical Time Series and Machine Learning Models in Inflation Forecasting in Türkiye

Dr. Öğr. Üyesi Zümre ÖZDEMİR GÜLER

Aydın Adnan Menderes Üniversitesi

zoguler@adu.edu.tr

https://orcid.org/0000-0003-2730-4584

Makale Başvuru Tarihi / Received: 13.07.2026

Makale Kabul Tarihi / Accepted: 31.08.2026

Makale Türü / Article Type: Araştırma Makalesi

ÖZET

Bu çalışmanın amacı, Türkiye’de aylık TÜFE enflasyonunun kısa dönemli öngörüsünde klasik zaman serisi modelleri ile makine öğrenmesi algoritmalarının tahmin performanslarını incelemektir. Bu amaçla 2014:05-2026:04 dönemini kapsayan aylık veri seti kullanılmış; modelleme sürecinde ARIMA ve SARIMAX modelleri ile Random Forest ve XGBoost algoritmaları karşılaştırılmıştır. Bağımlı değişken TÜFE endeksinden hesaplanan aylık logaritmik enflasyon oranıdır. Açıklayıcı değişkenler maliyet yönlü fiyat baskısını temsilen Yİ-ÜFE, kur geçişkenliğini temsilen USD/TL kuru, finansal koşulları temsilen faiz oranı, reel ekonomik aktiviteyi temsilen sanayi üretim endeksi ve dış maliyet kanalı temsilen Brent petrol fiyatıdır. Zaman serisi yapısı nedeniyle eğitim-test ayrımı rastgele yapılmamış; 2014:05-2024:04 dönemi başlangıç eğitim seti, 2024:05-2026:04 dönemi test seti olarak belirlenmiştir. Tahminler genişleyen pencere yaklaşımıyla bir adım ileri öngörü mantığına göre üretilmiş ve modeller MAE, RMSE ve MAPE ölçütleriyle karşılaştırılmıştır. Bulgular, ARIMA modelinin en düşük tahmin hatasını ürettiğini, SARIMAX modelinin ARIMA’ya yakın sonuç verdiğini, Random Forest ve XGBoost modellerinin ise mevcut veri yapısında daha yüksek hata değerleri ürettiğini göstermektedir. Bu sonuç, makine öğrenmesi algoritmalarının güçlü bir alternatif olmasına rağmen, küçük/orta ölçekli aylık makroekonomik veri setlerinde klasik zaman serisi modellerinin hâlâ rekabetçi ve hatta daha başarılı olabileceğini ortaya koymaktadır.

Anahtar Kelimeler: Enflasyon öngörüsü, ARIMA, SARIMAX, Random Forest, XGBoost, Türkiye.

ABSTRACT

This study compares the forecasting performance of classical time series models and machine learning algorithms in short-term monthly inflation forecasting for Türkiye. Using monthly data for the period 2014:05-2026:04, ARIMA and SARIMAX models are evaluated against Random Forest and XGBoost algorithms. The dependent variable is the monthly logarithmic inflation rate calculated from the consumer price index. Explanatory variables include domestic producer prices, the USD/TRY exchange rate, the interest rate, the industrial production index, and Brent crude oil prices, representing cost pressures, exchange rate pass-through, financial conditions, real economic activity, and external cost factors, respectively. Since the data have a time series structure, the training-test split is not random. The period 2014:05-2024:04 is used as the initial training period, while 2024:05-2026:04 is reserved as the test period. Forecasts are generated through an expanding-window one-step-ahead forecasting scheme and model performances are compared using MAE, RMSE, and MAPE. The empirical results show that the ARIMA model provides the lowest forecasting errors, followed closely by SARIMAX. In contrast, Random Forest and XGBoost produce relatively higher errors under the current data structure. These findings suggest that although machine learning algorithms offer considerable potential for inflation forecasting, classical time series models may remain highly competitive and even superior in small or medium-sized monthly macroeconomic datasets, particularly when short-term forecasting is the main objective.

Keywords: Inflation forecasting, ARIMA, SARIMAX, Random Forest, XGBoost, Türkiye.

1. GİRİŞ

Enflasyon, fiyat istikrarı, para politikası, gelir dağılımı, finansal kararlar ve ekonomik beklentiler üzerinde doğrudan etkisi bulunan temel makroekonomik göstergelerden biridir. Enflasyon oranının gelecekte izleyeceği seyrin doğru tahmin edilmesi, yalnızca merkez bankaları ve politika yapıcılar için değil, hanehalkları, firmalar, finansal kurumlar ve kamu maliyesi açısından da önem taşımaktadır. Fiyatlar genel düzeyindeki değişimlerin öngörülebilir olması, sözleşmelerin düzenlenmesi, ücret pazarlıkları, yatırım kararları, portföy tercihi, bütçe planlaması ve borçlanma stratejileri açısından belirleyici bir rol oynamaktadır. Bu nedenle enflasyon öngörüsü, uygulamalı makroekonomi, istatistik ve ekonometri literatüründe uzun süredir üzerinde çalışılan önemli bir tahmin problemidir.

Türkiye gibi enflasyon oynaklığının yüksek olduğu, döviz kuru hareketlerinin fiyatlama davranışı üzerinde belirgin etkiler yaratabildiği ve para politikası-finansal koşullar kanalının sıklıkla değişkenlik gösterdiği ekonomilerde enflasyon tahmini daha karmaşık hale gelmektedir. Türkiye ekonomisi son yıllarda kur şokları, enerji fiyatı dalgalanmaları, üretici fiyatlarındaki hızlı artışlar, talep koşullarındaki değişimler, küresel tedarik sorunları ve politika rejimindeki dönüşümler gibi çok sayıda iç ve dış faktörle karşı karşıya kalmıştır. Bu yapı, enflasyonun yalnızca kendi geçmiş değerleriyle değil, aynı zamanda çok sayıda makroekonomik değişkenle ilişkili karmaşık bir süreç olarak ele alınmasını gerektirmektedir. Bununla birlikte kısa dönemli öngörü çalışmalarında temel amaç, enflasyonun yapısal belirleyicilerini açıklamaktan çok, belirli bir tahmin ufkuyla olabildiğince düşük hata üreten modeli belirlemektir.

Enflasyon öngörüsü literatüründe uzun süre AR, ARMA, ARIMA, VAR, Phillips eğrisi ve faktör modelleri gibi klasik ekonometrik ve zaman serisi yaklaşımları öne çıkmıştır. Bu modeller görece açık bir yapıya sahip olmaları, az sayıda gözlemle çalışabilmeleri ve iktisadi yorumlama kolaylığı sağlamaları nedeniyle hâlâ güçlü bir benchmark niteliği taşımaktadır. Ancak son yıllarda hesaplama kapasitesindeki artış, yüksek boyutlu veri setlerine erişimin kolaylaşması ve doğrusal olmayan ilişkileri yakalama kapasitesi yüksek algoritmaların gelişmesiyle birlikte makine öğrenmesi yöntemleri enflasyon tahmininde giderek daha fazla kullanılmaya başlanmıştır. Random Forest, XGBoost, LASSO, Elastic Net, destek vektör makineleri, yapay sinir ağları ve LSTM gibi yöntemler, enflasyon dinamiklerinde yer alan karmaşık örüntüleri yakalama potansiyelleri nedeniyle güncel literatürde önemli bir yer edinmiştir.

Bununla birlikte makine öğrenmesi modellerinin klasik modellere koşulsuz biçimde üstün olduğu yönünde genel geçer bir sonuç bulunmamaktadır. Uluslararası literatürde bazı çalışmalar, özellikle veri-zengin ortamlarda ve çok sayıda potansiyel öngörü değişkeninin bulunduğu durumlarda makine öğrenmesi yöntemlerinin daha düşük tahmin hatası ürettiğini göstermektedir. Medeiros, Vasconcelos, Veiga ve Zilberman (2021), ABD enflasyonu için Random Forest modelinin önemli kazanımlar sağladığını ortaya koyarken; Araujo ve Gaglianone (2023), Brezilya örneğinde tek bir evrensel en iyi model olmadığını, ancak birçok durumda makine öğrenmesi yöntemlerinin geleneksel modellere göre avantajlı olabileceğini belirtmektedir. Buna karşılık Türkiye üzerine yapılan bazı çalışmalar, klasik zaman serisi modellerinin özellikle sınırlı gözlem yapısında veya belirli test dönemlerinde daha başarılı sonuçlar verebildiğini göstermektedir. Akbulut (2022), Türkiye enflasyonu için VAR modelinin bazı makine öğrenmesi modellerinden daha iyi performans gösterdiğini; Gayaker (2024) ise XGBoost'un kriz ve büyük veri seti koşullarında güçlü olmakla birlikte ARMA modelinin daha küçük veri setlerinde üstün olabileceğini vurgulamaktadır.

Bu tartışma, Türkiye'de enflasyon öngörüsünde farklı model sınıflarının aynı veri seti ve aynı test dönemi altında karşılaştırılmasının önemini artırmaktadır. Çalışmanın temel motivasyonu da buradan doğmaktadır. Bu çalışmada Türkiye'de aylık TÜFE enflasyonunun kısa dönemli öngörüsünde klasik zaman serisi modelleri ile makine öğrenmesi algoritmalarının performansları karşılaştırılmaktadır. Klasik zaman serisi yaklaşımını temsilen ARIMA ve SARIMAX modelleri; makine öğrenmesi yaklaşımını temsilen ise Random Forest ve XGBoost algoritmaları kullanılmıştır. ARIMA modeli enflasyonun kendi geçmiş değerlerine dayanan tek değişkenli klasik tahmin yaklaşımını temsil ederken, SARIMAX modeli aynı yapıya dışsal makroekonomik göstergeleri dahil etmektedir. Random Forest ve XGBoost ise gecikmeli enflasyon ve makroekonomik değişkenlerden oluşan özellik seti üzerinden doğrusal olmayan tahmin üretmektedir.

Çalışmada bağımlı değişken, TÜFE endeksinden hesaplanan aylık logaritmik enflasyon oranıdır. Açıklayıcı değişkenler ise Yİ-ÜFE, USD/TL döviz kuru, faiz oranı, sanayi üretim endeksi ve Brent petrol fiyatından oluşmaktadır. Bu değişkenler sırasıyla maliyet yönlü fiyat baskısını, kur geçişkenliğini, finansal koşulları, reel ekonomik aktiviteyi ve dış maliyet kanalını temsil etmektedir. Başlangıçta daha uzun bir dönem hedeflenmiş olmakla birlikte tüm değişkenlerde eksiksiz gözlem içeren ortak dönem veri uygunluğuna göre

belirlenmiş, ham veri seti 2014:01-2026:04 dönemini kapsamıştır. Dönüşümler ve gecikmeli değişkenlerin oluşturulması sonrasında modelleme veri seti 2014:05-2026:04 dönemini içermiştir.

Zaman serisi yapısı nedeniyle eğitim ve test ayrımı rastgele yapılmamıştır. Bu tercih, makine öğrenmesi uygulamalarında sıklıkla gözden kaçabilen veri sızıntısı sorununu önlemek açısından önemlidir. Çalışmada 2014:05-2024:04 dönemi başlangıç eğitim seti, 2024:05-2026:04 dönemi test seti olarak belirlenmiş; tahminler genişleyen pencere yaklaşımıyla bir adım ileri tahmin mantığına göre üretilmiştir. Böylece her test ayı için yalnızca ilgili aydan önceki bilgiler kullanılmış ve model performansları gerçekçi bir örneklem dışı tahmin çerçevesinde değerlendirilmiştir. Performans karşılaştırmasında MAE, RMSE ve MAPE ölçütlerinden yararlanılmıştır.

Çalışmanın temel araştırma soruları şu şekilde özetlenebilir: Türkiye’de aylık TÜFE enflasyonunun kısa dönemli öngörüsünde klasik zaman serisi modelleri başarılı tahmin performansı göstermekte midir? Makine öğrenmesi algoritmaları klasik modellere kıyasla daha düşük tahmin hatası üretmekte midir? Açıklayıcı makroekonomik değişkenlerin modele dahil edilmesi tahmin performansını artırmakta mıdır? ARIMA, SARIMAX, Random Forest ve XGBoost modelleri arasında MAE, RMSE ve MAPE ölçütlerine göre en başarılı model hangisidir? Son olarak, Türkiye’de enflasyon öngörüsü için doğrusal/parametrik modeller ile doğrusal olmayan makine öğrenmesi yaklaşımları arasında belirgin bir performans farkı var mıdır?

Bu çalışma, literatüre üç açıdan katkı sunmayı amaçlamaktadır. Birincisi, Türkiye’de güncel aylık veriler üzerinden klasik zaman serisi modelleri ile makine öğrenmesi algoritmalarını aynı tahmin tasarımı içinde karşılaştırmaktadır. İkincisi, zaman serisi yapısına uygun genişleyen pencere yaklaşımını kullanarak rastgele eğitim-test ayrımından doğabilecek yanlılığı önlemektedir. Üçüncüsü, yalnızca model performanslarını karşılaştırmakla kalmayıp, makine öğrenmesi modellerinde değişken önemlerini de inceleyerek geçmiş enflasyon, üretici fiyatları ve döviz kuru değişimlerinin tahmin sürecindeki rolünü ortaya koymaktadır. Elde edilen bulgular, ARIMA modelinin incelenen dönemde en düşük hata değerlerini ürettiğini göstermekte ve enflasyon öngörüsünde model seçiminin algoritmanın karmaşıklığından ziyade veri yapısı, tahmin ufku ve örneklem özellikleriyle birlikte değerlendirilmesi gerektiğine işaret etmektedir.

2. KAVRAMSAL ÇERÇEVE

Enflasyon öngörüsü kavramsal olarak, fiyatlar genel düzeyindeki geleceğe dönük değişimin geçmiş gözlemler ve ilgili makroekonomik göstergeler kullanılarak tahmin edilmesi sürecidir. Bu süreçte tahmin edilen değişken genellikle belirli bir fiyat endeksinden hesaplanan enflasyon oranıdır. Bu çalışmada enflasyon, TÜFE endeksinin aylık logaritmik değişimi olarak tanımlanmaktadır. Logaritmik değişim, fiyat endeksindeki göreceli hareketleri sürekli bileşik değişim mantığıyla ifade ettiği için zaman serisi ve öngörü çalışmalarında yaygın biçimde kullanılmaktadır. Aylık frekansta çalışılması, kısa dönemli fiyat hareketlerinin ve politika açısından yakın dönemli izleme ihtiyacının ön plana çıkarılmasını sağlamaktadır.

Enflasyonun kısa dönemli öngörüsü ile enflasyonun yapısal açıklaması birbirinden farklı ancak ilişkili iki araştırma amacını temsil eder. Yapısal açıklama odaklı çalışmalarda enflasyonun para arzı, çıktı açığı, beklentiler, kur geçişkenliği, ücretler veya maliyet unsurları gibi teorik belirleyicilerle ilişkisi incelenir. Tahmin odaklı çalışmalarda ise esas ölçüt modelin gelecek dönem değerlerini ne kadar düşük hata ile öngördüğüdür. Bu nedenle tahmin çalışmalarında modelin istatistiksel doğruluğu, örneklem dışı performansı ve hata ölçütleri ön plana çıkar. Bu çalışma ikinci çizgide konumlanmakta; enflasyonun nihai yapısal belirleyicilerini test etmekten ziyade farklı model sınıflarının tahmin başarısını karşılaştırmaktadır.

Klasik zaman serisi yaklaşımı, bir değişkenin geçmiş değerlerindeki düzenliliklerin gelecek dönem değerleri hakkında bilgi taşıdığı varsayımına dayanır. ARIMA modelleri bu yaklaşımın en yaygın kullanılan örneklerinden biridir. ARIMA modelinde serinin otoregresif yapısı, fark alma derecesi ve hata terimlerinin hareketli ortalama bileşeni birlikte ele alınır. Bu yönüyle ARIMA modeli, enflasyonun kendi geçmiş değerlerinden hareketle tahmin üreten tek değişkenli ve parametrik bir modeldir. Enflasyon serilerinde gecikmeli uyarlanma, süreklilik, yapışkanlık veya kısa dönemli ataletle bağlı hareketler bulunduğu ARIMA modelleri oldukça güçlü sonuçlar verebilir. Özellikle aylık veri gibi gözlem sayısının sınırlı olduğu yapılarda ARIMA modelleri, aşırı karmaşık olmayan ve düzenli biçimde uygulanabilen sağlam bir benchmark niteliği taşır.

SARIMAX modeli ise ARIMA yaklaşımını mevsimsel bileşenler ve dışsal değişkenlerle genişletir. Bu model, enflasyonun yalnızca kendi geçmiş değerlerinden değil, aynı zamanda üretici fiyatları, döviz kuru, faiz oranları, reel aktivite ve enerji fiyatları gibi değişkenlerden etkilenebileceği varsayımını klasik zaman serisi çerçevesine dahil eder. Türkiye ekonomisinde ithal girdi bağımlılığı, kur geçişkenliği, üretici

fiyatlarından tüketici fiyatlarına aktarım ve enerji fiyatı şokları dikkate alındığında, SARIMAX modeli teorik olarak ARIMA'ya göre daha zengin bir bilgi seti sunmaktadır. Ancak dışsal değişkenlerin eklenmesi tahmin performansını her zaman artırmayabilir. Ek değişkenler modelin bilgi setini genişletirken aynı zamanda parametre belirsizliğini, model karmaşıklığını ve örneklem içi uyumun örneklem dışı performansa taşınmaması riskini de artırabilir.

Makine öğrenmesi yaklaşımı, tahmin problemine farklı bir bakış sunar. Geleneksel ekonometrik modeller çoğunlukla belirli bir fonksiyonel form varsayar ve parametrelerin istatistiksel anlamlılığına odaklanır. Buna karşılık makine öğrenmesi algoritmaları, değişkenler arasındaki ilişki biçimini daha esnek biçimde öğrenmeye çalışır. Random Forest ve XGBoost gibi ağaç tabanlı yöntemler, doğrusal olmayan ilişkileri, eşik etkilerini ve değişkenler arası etkileşimleri yakalama kapasitesine sahiptir. Bu özellik, enflasyon gibi çok sayıda değişkenin birlikte etilediği ve dönemsel olarak farklılaşabilen bir değişkenin tahmininde önemli bir avantaj sağlayabilir. Masini, Medeiros ve Mendes (2021), makine öğrenmesi yöntemlerinin zaman serisi tahmininde doğrusal düzenleme modellerinden ağaç tabanlı topluluk yöntemlerine ve derin öğrenme yaklaşımlarına kadar geniş bir araç seti sunduğunu belirtmektedir.

Random Forest, çok sayıda karar ağacının bir araya getirilmesiyle oluşturulan bir topluluk öğrenmesi algoritmasıdır. Her ağaç farklı alt örneklem ve değişken kombinasyonlarıyla tahmin üretir; nihai tahmin bu ağaçların ortalaması olarak elde edilir. Bu yapı tekil karar ağaçlarının yüksek varyansını azaltır ve modelin daha dengeli tahmin üretmesini sağlar. Random Forest'in enflasyon öngörüsünde öne çıkmasının temel nedeni, doğrusal olmayan ilişkileri ve değişken etkileşimlerini görece az hiperparametre gereksinimiyle yakalayabilmesidir. Medeiros vd. (2021), veri-zengin bir ortamda Random Forest modelinin ABD enflasyon tahmininde güçlü performans gösterdiğini ve başarısının hem değişken seçimi hem de doğrusal olmayanlıkla ilişkili olduğunu göstermiştir. Makroekonomik öngörü çalışmalarında Random Forest gibi esnek algoritmaların kullanımı, doğrusal olmayan ilişkilerin ve değişken etkileşimlerinin modellenmesine olanak sağlaması bakımından Goulet Coulombe (2021) tarafından da vurgulanmaktadır.

XGBoost, gradyan artırma yaklaşımına dayalı güçlü bir ağaç tabanlı algoritmadır. Bu yöntemde karar ağaçları ardışık biçimde kurulur ve her yeni ağaç önceki ağaçların hatalarını azaltmayı hedefler. XGBoost'un düzenleme yapısı, değişken önemleri üretmesi ve karmaşık ilişkileri modelleyebilmesi önemli avantajlar olarak kabul edilir. Bununla birlikte bu model hiperparametre seçimine ve eğitim veri setinin büyüklüğüne duyarlıdır. Küçük veya orta ölçekli aylık veri setlerinde XGBoost'un aşırı öğrenme riski oluşabilir. Bu nedenle XGBoost'un performansı, veri setinin büyüklüğü, değişken sayısı, gecikme yapısı ve test döneminin özellikleriyle yakından ilişkilidir.

Bu çalışmada kullanılan makroekonomik değişkenler enflasyonun başlıca kısa dönemli kanallarını temsil edecek şekilde belirlenmiştir. Yİ-ÜFE, üretici maliyetlerindeki değişimleri yansıtarak tüketici fiyatlarına potansiyel geçişi temsil eder. USD/TL kurundaki değişimler, ithal girdi maliyetleri ve beklenti kanalı üzerinden enflasyon üzerinde etkili olabilir. Faiz oranı, para politikası ve finansal koşulların göstergesi olarak kullanılmıştır. Sanayi üretim endeksi reel ekonomik aktiviteyi ve talep koşullarını temsil etmektedir. Brent petrol fiyatı ise enerji ithalatçısı ülkelerde dış maliyet baskısının önemli bir göstergesidir. Kohlscheen (2022), petrol fiyatları ve küresel üretici fiyatları gibi dışsal maliyet unsurlarının enflasyonun belirleyicileri arasında yer alabildiğini göstermektedir.

Kavramsal olarak bu çalışma, makine öğrenmesi algoritmalarının koşulsuz üstünlüğünü varsaymamaktadır. Bunun yerine model performansının veri yapısı, örneklem uzunluğu, tahmin ufku, değişken seti ve ülke dinamiklerine bağlı olduğunu kabul etmektedir. Bu yaklaşım, son dönem literatürde giderek güçlenen bağlamsallık vurgusuyla uyumludur. Araujo ve Gaglianone (2023), Brezilya için çok sayıda model ve değişken kullandıkları kapsamlı karşılaştırmada tek bir evrensel en iyi modelin bulunmadığını göstermiştir. Akbulut (2022) ve Gayaker (2024) gibi Türkiye odaklı çalışmalar da klasik zaman serisi modellerinin belirli veri yapılarında makine öğrenmesi modellerinden daha başarılı olabileceğini ortaya koymaktadır. Bu nedenle mevcut çalışma, model seçimini yöntemsel gelişmişlik düzeyine göre değil, örneklem dışı tahmin performansına göre değerlendirmektedir.

3. LİTERATÜR TARAMASI

Enflasyon öngörüsü literatürünün gelişimi, klasik ekonometrik modellerden veri-zengin ortamlarda makine öğrenmesi uygulamalarına doğru ilerleyen bir dönüşüm göstermektedir. Erken dönem çalışmalar çoğunlukla Phillips eğrisi, parasal modeller, AR/ARMA/ARIMA modelleri, VAR modelleri ve faktör modelleri üzerine kuruludur. Bu yaklaşımlarda enflasyonun ekonomik belirleyicileriyle ilişkisi ve geçmiş değerlerinin tahmin

gücü birlikte değerlendirilmiştir. Ancak literatürde basit tek değişkenli benchmark modellerin sistematik biçimde aşılmasının güç olduğu sıkça belirtilmiştir. Bu durum, araştırmacıları daha geniş veri setleri, boyut indirgeme yöntemleri, düzenleme teknikleri ve makine öğrenmesi algoritmaları kullanmaya yöneltmiştir.

Makine öğrenmesi yöntemlerinin enflasyon öngörüsündeki yükselişi özellikle 2015 sonrası dönemde belirginleşmiştir. Hesaplama kapasitesinin artması, merkez bankalarının ve uluslararası veri tabanlarının daha zengin veri setleri sunması, algoritmaların uygulanabilirliğini artırmıştır. Bu dönemde LASSO, Ridge, Elastic Net, Random Forest, Gradient Boosting, XGBoost, destek vektör makineleri, yapay sinir ağları ve LSTM gibi yöntemler enflasyon tahmini çalışmalarında daha fazla yer almaya başlamıştır. Bu yöntemlerin ortak özelliği, klasik modellerin önceden belirlenmiş fonksiyonel form kısıtlarını gevşetmesi ve değişkenler arasındaki doğrusal olmayan ilişkileri daha esnek biçimde modelleyebilmesidir.

Medeiros, Vasconcelos, Veiga ve Zilberman (2021), enflasyon öngörüsünde makine öğrenmesi yöntemlerinin gücünü gösteren temel çalışmalardan biridir. ABD enflasyonu için veri-zengin bir ortamda çok sayıda makroekonomik değişken ve çeşitli makine öğrenmesi yöntemleri kullanılmıştır. Çalışmada Random Forest modelinin, rassal yürüyüş, AR, UCSV, faktör modelleri ve düzenleme temelli bazı alternatiflere kıyasla güçlü performans gösterdiği belirtilmektedir. Yazarlar, Random Forest modelinin başarısını yalnızca değişken seçimiyle değil, aynı zamanda enflasyon ile makroekonomik göstergeler arasındaki doğrusal olmayan ilişkileri yakalayabilmesiyle açıklamaktadır. Bu sonuç, enflasyon öngörüsünde büyük veri setleri ve esnek algoritmaların birlikte kullanılmasının önemli tahmin kazanımları sağlayabileceğini göstermektedir.

Araujo ve Gaglianone (2023), Brezilya enflasyonu için yaptıkları kapsamlı çalışmada 501 seri ve 50 farklı tahmin yöntemini karşılaştırmıştır. Çalışmada ARMA, VAR, Phillips eğrisi, faktör modelleri, anket beklentileri, finansal piyasa beklentileri, LASSO, Ridge, Elastic Net, Random Forest, Quantile Regression Forest, XGBoost, RNN ve tahmin kombinasyonları yer almaktadır. Bulgular, tek bir evrensel en iyi model bulunmadığını; ancak çok sayıda durumda makine öğrenmesi yöntemlerinin geleneksel ekonometrik modellere kıyasla daha iyi sonuç verebildiğini göstermektedir. Özellikle ağaç tabanlı yöntemler, tahmin kombinasyonları ve beklenti göstergeleri öne çıkmaktadır. Bu çalışma, gelişmekte olan bir ekonomi bağlamında kapsamlı model karşılaştırması sunması bakımından mevcut çalışma için önemli bir referans niteliğindedir.

Rodríguez-Vargas (2020), Kosta Rika enflasyonu için makine öğrenmesi yöntemlerinin tahmin performansını incelemiştir. Çalışmada KNN, Random Forest, XGBoost ve LSTM modelleri uygulanmış; ayrıca tahminlerin optimal tahmin literatüründe yer alan özellikleri değerlendirilmiştir. Bulgular, LSTM, tek değişkenli KNN ve kısmen Random Forest modellerinin başarılı sonuçlar verdiğini, tahmin kombinasyonlarının ise bireysel modellere göre daha iyi performans gösterebildiğini göstermektedir. Çalışmanın mevcut araştırma açısından en önemli katkılarından biri, zaman serisi verilerinde rastgele eğitim-test ayırımının uygun olmadığını vurgulamasıdır. Gözlemlerin zamansal sırasının korunması ve rolling-origin veya genişleyen pencere mantığıyla model değerlendirmesi yapılması gerektiği belirtilmiştir. Bu yaklaşım, mevcut çalışmada kullanılan genişleyen pencere öngörü tasarımıyla doğrudan uyumludur.

Aras ve Lisboa (2022), Türkiye enflasyonu için açıklanabilir makine öğrenmesi yaklaşımını kullanan önemli çalışmalardan biridir. Çalışmada faktör modelleri, özellik seçimi, ağaç tabanlı modeller ve Shapley değerleri birlikte ele alınmıştır. Yazarlar, Türkiye gibi yüksek enflasyon oynaklığı ve belirsizlik içeren bir ekonomide ağaç tabanlı topluluk modellerinin hem tahmin doğruluğu hem de açıklanabilirlik bakımından avantaj sağlayabileceğini göstermektedir. Bu çalışma, makine öğrenmesi modellerinin yalnızca tahmin üretmek için değil, aynı zamanda tahminlerde hangi değişkenlerin daha etkili olduğunu anlamak için de kullanılabileceğini ortaya koymaktadır. Mevcut çalışmada Random Forest ve XGBoost değişken önemlerinin raporlanması bu açıklanabilirlik çizgisiyle uyumludur.

Kohlscheen (2022), 20 gelişmiş ülke için Random Forest modelini kullanarak enflasyonun belirleyicilerini incelemiştir. Çalışmanın bulguları, enflasyon beklentileri ve geçmiş enflasyonun öne çıkan değişkenler olduğunu, petrol fiyatları ve küresel üretici fiyatları gibi dışsal maliyet göstergelerinin de enflasyon üzerinde etkili olabileceğini göstermektedir. Bu sonuç, mevcut çalışmada Yİ-ÜFE, Brent petrol fiyatı, döviz kuru ve geçmiş enflasyon gecikmelerine yer verilmesini desteklemektedir. Enflasyon tahmininde yalnızca geçmiş fiyat hareketleri değil, maliyet ve dışsal şok göstergelerinin de dikkate alınması gerektiği literatürde giderek daha fazla vurgulanmaktadır.

Boaretto ve Medeiros (2023), Brezilya için ayrıştırılmış enflasyon bileşenlerinden hareketle toplam enflasyonun tahmin edilmesini ele almıştır. Bottom-up yaklaşım olarak adlandırılan bu yöntemde, fiyat endeksinin alt bileşenlerine ilişkin tahminler üretilmekte ve bu tahminler ağırlıklandırılarak toplam enflasyon tahmini elde edilmektedir. Çalışma, geleneksel zaman serisi modelleri ile doğrusal ve doğrusal olmayan makine öğrenmesi yöntemlerini birlikte değerlendirmektedir. Bulgular, özellikle oynak dönemlerde ayrıştırılmış fiyat bileşenleriyle makine öğrenmesi yöntemlerinin birlikte kullanılmasının tahmin performansını artırabileceğini göstermektedir. Bu sonuç mevcut çalışma açısından gelecekteki genişletme alanlarını işaret etmektedir. Türkiye için TÜFE alt kalemleri, beklenti verileri ve yüksek frekanslı göstergeler modele dahil edildiğinde makine öğrenmesi algoritmalarının performansı farklılaşabilir.

Liu, Pan ve Xu (2024), Japonya için pandemi sonrası çekirdek enflasyon tahmininde makine öğrenmesi yöntemlerini kullanmıştır. Çalışmada LASSO, Elastic Net, Random Forest ve XGBoost modelleri benchmark AR ve Random Walk modelleriyle karşılaştırılmıştır. Bulgular, 2022 sonrası dönemde LASSO modelinin güçlü performans gösterdiğini ortaya koymaktadır. Bu sonuç, her zaman en karmaşık veya en doğrusal olmayan modelin en iyi sonucu vermediğini göstermesi bakımından önemlidir. Düzenleştirilmiş doğrusal modeller, belirli veri yapılarında ve tahmin ufuklarında ağaç tabanlı modellere göre daha başarılı olabilir. Bu bulgu, model performansının bağlamsal olarak değerlendirilmesi gerektiği yönündeki temel argümanı desteklemektedir.

Türkiye özelindeki çalışmalar mevcut araştırmanın konumlandırılması açısından ayrıca önemlidir. Akbulut (2022), Türkiye’de 2006:M1-2020:M12 dönemi için zaman serisi modelleri ile makine öğrenmesi modellerini karşılaştırmıştır. Çalışmada VAR modeli ile Ridge, Lasso ve MLP modelleri değerlendirilmiş; RMSE ve R^2 ölçütlerine göre VAR modelinin ML algoritmalarından daha başarılı olduğu görülmüştür. Bununla birlikte MLP modelinin Lasso ve Ridge gibi doğrusal ML modellerinden daha iyi sonuç verdiği belirtilmiştir. Bu sonuç, Türkiye enflasyonunda doğrusal olmayan yapıların var olabileceğini, ancak sınırlı veri yapısında klasik zaman serisi modellerinin hâlâ güçlü performans gösterebildiğini ortaya koymaktadır.

Gayaker (2024), Türkiye’de ekonomik şoklar ve krizler bağlamında XGBoost ve ARMA modellerinin performansını karşılaştırmıştır. 1990:02-2024:06 dönemini kapsayan çalışmada XGBoost’un geniş veri setleri ve kriz dönemlerinde güçlü performans gösterebildiği, ARMA modelinin ise daha küçük veri setlerinde daha iyi sonuç verebildiği belirtilmiştir. Özellikle ARMA modelinden gelen gecikmeli değişkenlerin XGBoost’a entegre edilmesiyle oluşturulan hibrit modelin kriz dönemlerinde daha etkili olduğu vurgulanmıştır. Bu bulgu, zaman serisi dinamiklerinin makine öğrenmesi modellerine aktarılmasının önemini ortaya koymaktadır. Mevcut çalışmada da Random Forest ve XGBoost modellerinde enflasyon ve makroekonomik değişkenlerin gecikmeli değerlerinden oluşan özellik seti kullanılmıştır.

Nalıcı, Söylemez ve Ünlü (2025), Türkiye TÜFE tahmini için Decision Tree, Random Forest ve Support Vector Machine modellerini kullanmış; SelectKBest yöntemiyle belirlenen önemli endeksler üzerinden model performanslarını değerlendirmiştir. Çalışmada Random Forest modelinin birçok tahmin ufukunda güçlü performans gösterdiği ve ensemble yaklaşımının bireysel modellerden daha güvenilir tahmin ürettiği belirtilmektedir. Bu çalışma, Türkiye’de TÜFE tahmininde özellik seçimi ve ensemble yaklaşımlarının önemini göstermesi bakımından değerlidir. Ancak mevcut çalışma, daha sınırlı ve iktisadi gerekçesi açık bir makroekonomik değişken setiyle klasik zaman serisi modelleri ve ağaç tabanlı ML algoritmalarını doğrudan karşılaştırması bakımından farklılaşmaktadır.

Literatür genel olarak değerlendirildiğinde üç temel sonuç öne çıkmaktadır. Birincisi, makine öğrenmesi modelleri özellikle veri-zengin ortamlarda, çok sayıda değişkenin bulunduğu yapılarda ve doğrusal olmayan ilişkilerin belirgin olduğu dönemlerde güçlü performans gösterebilir. İkincisi, zaman serisi verilerinde model değerlendirmesi yapılırken rastgele eğitim-test ayrımı yerine zamansal sıralamayı koruyan yaklaşımlar kullanılmalıdır. Üçüncüsü, klasik zaman serisi modelleri özellikle sınırlı gözlem yapısında, kısa dönemli tahmin ufuklarında ve enflasyonun kendi geçmiş değerlerinin güçlü bilgi içerdiği durumlarda hâlâ rekabetçi olabilir. Mevcut çalışma, bu üç bulguyu Türkiye aylık enflasyon verisi üzerinde aynı tahmin tasarımı içinde sınamaktadır.

Tablo 1: Seçilmiş Çalışmaların Karşılaştırmalı Özeti

Çalışma	Ülke/Dönem	Yöntemler	Temel bulgu
Medeiros vd. (2021)	ABD / veri-zengin ortam	LASSO, Ridge, RF, faktör modelleri	Random Forest veri-zengin ortamda güçlü performans göstermiştir.
Rodríguez-Vargas (2020)	Kosta Rika / aylık veri	KNN, RF, XGBoost, LSTM	LSTM, KNN ve RF başarılı; kombinasyonlar performansı artırmıştır.
Akbulut (2022)	Türkiye / 2006:M1-2020:M12	VAR, Ridge, Lasso, MLP	VAR, ML modellerinden daha başarılı bulunmuştur.
Aras ve Lisboa (2022)	Türkiye	Ağaç tabanlı ML, faktör modelleri, SHAP	Ağaç tabanlı modeller doğruluk ve açıklanabilirlik sağlamıştır.
Araujo ve Gaglianone (2023)	Brezilya / 501 seri	50 yöntem: ARMA, VAR, RF, XGBoost, RNN	Evrensel en iyi model yok; birçok durumda ML avantajlıdır.
Gayaker (2024)	Türkiye / 1990:02-2024:06	XGBoost, ARMA, hibrit yapı	XGBoost krizlerde; ARMA küçük veri setlerinde güçlü olabilir.
Liu vd. (2024)	Japonya / pandemi sonrası	LASSO, Elastic Net, RF, XGBoost	LASSO en iyi performansı göstermiştir.

4. VERİ SETİ VE DEĞİŞKENLER

Çalışmada Türkiye’de aylık enflasyonun kısa dönemli öngörüsünü incelemek amacıyla aylık frekansta makroekonomik değişkenlerden oluşan bir veri seti kullanılmıştır. Başlangıçta 2010 sonrası dönem hedeflenmiş olmakla birlikte, tüm değişkenlerde eksiksiz gözlem içeren ortak dönem veri uygunluğuna göre belirlenmiştir. Bu kapsamda ham veri setinin ortak dönemi 2014:01-2026:04 olarak oluşmuştur. Faiz oranı değişkeninin aylık değişim olarak kullanılması ve makine öğrenmesi modelleri için gecikmeli değişkenlerin oluşturulması sonrasında, modelleme veri seti 2014:05–2026:04 dönemini kapsayacak şekilde düzenlenmiştir. Böylece model tahmini için kullanılan veri seti, tüm değişkenlerde eksiksiz gözlem içeren düzenli aylık zaman serisi yapısına dönüştürülmüştür.

Bağımlı değişken aylık TÜFE enflasyon oranıdır. TÜFE endeksi kullanılarak aylık logaritmik yüzde değişim hesaplanmıştır. Bu dönüşüm, fiyat endeksindeki aylık değişimi yaklaşık yüzde oranı olarak ifade etmekte ve serinin kısa dönemli dalgalanmalarını analiz etmeye olanak sağlamaktadır. Açıklayıcı değişkenler maliyet yönlü fiyat baskısını temsilen Yİ-ÜFE, kur geçişkenliğini temsilen USD/TL döviz kuru, para politikası ve finansal koşulları temsilen faiz oranı, reel ekonomik aktiviteyi temsilen sanayi üretim endeksi ve dış maliyet unsurunu temsilen Brent petrol fiyatından oluşmaktadır. TÜFE, Yİ-ÜFE, USD/TL, faiz oranı ve sanayi üretim endeksi serileri TCMB Elektronik Veri Dağıtım Sistemi (EVDS) üzerinden; Brent petrol fiyatı ise FRED veri tabanındaki Brent-Europe serisi üzerinden elde edilmiştir. Çalışmada kullanılan değişkenler, kodları ve dönüşüm biçimleri Tablo 2’de sunulmaktadır.

Tablo 2: Çalışmada Kullanılan Değişkenler

Değişken	Kod	Temsil ettiği unsur	Dönüşüm
TÜFE enflasyonu	inf	Bağımlı değişken	$100 \times \Delta \ln(TÜFE)$
Yİ-ÜFE değişimi	ppi	Maliyet yönlü fiyat baskısı	$100 \times \Delta \ln(Yİ - ÜFE)$
USD/TL değişimi	fx	Kur geçişkenliği	$100 \times \Delta \ln(USD/TL)$
Faiz oranı değişimi	int	Para politikası/finansal koşullar	$\Delta Faiz oranı$
Sanayi üretimi değişimi	ipi	Reel ekonomik aktivite	$100 \times \Delta \ln(SÜE)$
Brent petrol değişimi	brent	Dış maliyet unsuru	$100 \times \Delta \ln(Brent)$

Kaynak: TÜFE, Yİ-ÜFE, USD/TL, faiz oranı ve sanayi üretim endeksi serileri TCMB Elektronik Veri Dağıtım Sistemi (EVDS) (<https://evds3.tcmb.gov.tr>); Brent petrol fiyatı FRED veri tabanındaki Brent-Europe serisi (<https://fred.stlouisfed.org/series/DCOILBRETEU>) üzerinden alınmıştır.

Değişken dönüşümleri modelleme açısından kritik öneme sahiptir. TÜFE, Yİ-ÜFE, USD/TL, sanayi üretim endeksi ve Brent petrol fiyatı serileri için aylık logaritmik yüzde değişim ($100 \times \Delta \ln(x_t)$) hesaplanmıştır. Bu dönüşüm, ilgili endeks veya fiyat serilerindeki aylık oransal hareketleri göstermektedir. Faiz oranı ise düzey serisinde durağanlık sorunu göstermesi nedeniyle aylık fark biçiminde kullanılmıştır. Makine öğrenmesi modellerinde hedef değişken TÜFE enflasyonu olup, özellik seti hem bağımlı değişkenin hem de açıklayıcı değişkenlerin 1, 2 ve 3 dönem gecikmeli değerlerinden oluşturulmuştur. Böylece RF ve XGBoost modellerinde t dönemindeki enflasyon, yalnızca $t - 1$, $t - 2$ ve $t - 3$ dönemlerinde gözlemlenmiş bilgiler

kullanılarak tahmin edilmiştir. Bu gecikme yapısı, veri sızıntısını önlemekte ve zaman serisi yapısına uygun bir öngörü çerçevesi sunmaktadır.

Veri setinin genel yapısını değerlendirmek amacıyla değişkenlere ilişkin tanımlayıcı istatistikler hesaplanmıştır. Tanımlayıcı istatistikler, değişkenlerin ortalama düzeyleri, oynaklıkları ve uç değerleri hakkında ön bilgi sunarak modelleme öncesi veri yapısının anlaşılmasını sağlamaktadır. Bu sonuçlar Tablo 3'te verilmiştir.

Tablo 3: Tanımlayıcı İstatistikler

Değişken	N	Ortalama	Std. Sapma	Minimum	Medyan	Maksimum
TÜFE enflasyonu	147	1,937	2,057	-1,453	1,353	12,730
Yİ-ÜFE değişimi	147	2,138	2,636	-2,563	1,514	17,466
USD/TL değişimi	147	2,043	4,227	-8,656	1,537	25,121
Faiz oranı değişimi	147	0,204	1,752	-4,200	0,000	8,090
Sanayi üretimi değişimi	147	0,333	4,318	-34,694	0,421	17,110
Brent petrol değişimi	147	-0,033	9,702	-49,501	0,969	35,918

Tanımlayıcı istatistiklere göre çalışma döneminde Türkiye'de aylık TÜFE enflasyonunun ortalaması %1,94, standart sapması ise yaklaşık 2,06'dır. Enflasyon serisinin minimum değeri -%1,45, maksimum değeri ise %12,73 olarak hesaplanmıştır. Bu geniş aralık, incelenen dönemde fiyat hareketlerinin zaman zaman oldukça yüksek oynaklık sergilediğini göstermektedir. Yİ-ÜFE değişiminin ortalaması %2,14, standart sapması ise 2,64'tür. Üretici fiyatlarındaki maksimum aylık değişimin %17,47'ye ulaşması, maliyet baskılarının belirli dönemlerde tüketici fiyatlarından daha yüksek dalgalanma gösterebildiğini düşündürmektedir.

USD/TL değişiminin standart sapması 4,23, Brent petrol değişiminin standart sapması ise 9,70'tir. Bu bulgular, kur ve enerji fiyatı göstergelerinin yüksek oynaklığa sahip olduğunu göstermektedir. Sanayi üretim endeksi değişiminin ortalaması pozitif olmakla birlikte, minimum değerinin -%34,69'a kadar düşmesi reel ekonomik aktivitede belirli dönemlerde sert daralmalar yaşandığına işaret etmektedir. Bu durum özellikle pandemi ve benzeri şok dönemlerinin veri setine yansımalarıyla ilişkilendirilebilir. Faiz oranı değişiminin ortalaması 0,20, standart sapması ise 1,75'tir. Faiz oranının bazı aylarda yüksek artış veya düşüş göstermesi, para politikası ve finansal koşullarda dönemsel değişimlerin belirgin olduğunu göstermektedir.

Genel olarak tanımlayıcı istatistikler, Türkiye'de aylık enflasyon öngörüsünün yüksek oynaklık içeren çok boyutlu bir makroekonomik ortamda yapıldığını ortaya koymaktadır. Bu nedenle modelleme sürecinde yalnızca değişkenlerin ortalama eğilimleri değil, aynı zamanda oynaklık düzeyleri, uç değerler ve dönemsel kırılmalar da dikkate alınmalıdır.

Modelleme öncesinde değişkenlerin zaman serisi özellikleri incelenmiş, gerekli dönüşümler uygulanmış ve serilerin durağanlık durumları ADF birim kök testiyle değerlendirilmiştir. ADF testine ilişkin sonuçlar Bulgular bölümünde sunulmuştur.

5. YÖNTEM

Türkiye'de aylık TÜFE enflasyonunun kısa dönemli öngörüsünde klasik zaman serisi modelleri ile makine öğrenmesi algoritmalarının tahmin performansları karşılaştırmalı olarak değerlendirilmiştir. Klasik zaman serisi yaklaşımını temsilen ARIMA ve SARIMAX modelleri; makine öğrenmesi yaklaşımını temsilen Random Forest ve XGBoost algoritmaları kullanılmıştır. Böylece yalnızca enflasyon serisinin kendi geçmiş bilgisinden yararlanan tek değişkenli bir model, dışsal makroekonomik değişkenleri içeren klasik bir zaman serisi modeli ve doğrusal olmayan ilişkileri yakalayabilen iki farklı makine öğrenmesi algoritması aynı öngörü çerçevesinde incelenmiştir. Zaman serisi öngörüsünde makine öğrenmesi yöntemlerinin kullanımı, özellikle doğrusal olmayan ilişkilerin ve değişkenler arası etkileşimlerin yakalanabilmesi açısından son yıllarda yaygınlaşmıştır (Masini vd., 2021; Medeiros vd., 2021).

ARIMA modeli, Box-Jenkins zaman serisi modelleme yaklaşımı çerçevesinde aylık TÜFE enflasyonunun geçmiş değerleri ve hata terimleri üzerinden tahmin üreten tek değişkenli bir model olarak kurulmuştur (Box vd., 2015). Genel olarak ARIMA modeli şu şekilde ifade edilebilir:

$$\phi(L)(1-L)^d y_t = c + \theta(L)\varepsilon_t$$

Burada y_t aylık TÜFE enflasyonunu, L gecikme operatörünü, p otoregresif gecikme derecesini, d fark alma derecesini, q hareketli ortalama derecesini ve ε_t hata terimini göstermektedir. ARIMA modeli, yalnızca bağımlı değişkenin geçmiş değerlerinden yararlanması nedeniyle çalışmada temel klasik zaman serisi benchmark modeli olarak kullanılmıştır.

SARIMAX modeli ise ARIMA yapısına dışsal değişkenlerin eklenmesiyle oluşturulmuştur. Bu modelde Yİ-ÜFE değişimi, USD/TL değişimi, faiz oranı değişimi, sanayi üretimi değişimi ve Brent petrol değişimi dışsal değişkenler olarak kullanılmıştır. SARIMAX modeli genel olarak şu biçimde gösterilebilir:

$$\phi(L)(1-L)^d y_t = c + \beta' X_t + \theta(L)\varepsilon_t$$

Burada X_t modele dahil edilen dışsal makroekonomik değişkenler vektörünü, β ise bu değişkenlere ait katsayılar vektörünü ifade etmektedir. ARIMA ve SARIMAX modellerinde uygun p , d ve q değerleri, belirlenen aday model seti içinde Akaike Bilgi Kriteri'ni (AIC) en düşük yapan model yapısı esas alınarak seçilmiştir (Akaike, 1974). SARIMAX modelinde dışsal değişkenler aynı tahmin çerçevesinde değerlendirilmiş ve model seçimi karşılaştırılabilirlik amacıyla yine AIC ölçütüne dayandırılmıştır.

Random Forest ve XGBoost modelleri, makine öğrenmesi yaklaşımını temsil etmektedir. Random Forest modeli, Breiman (2001) tarafından geliştirilen topluluk öğrenmesi yaklaşımına dayalı olarak kurulmuştur. XGBoost modeli ise Chen ve Guestrin (2016) tarafından geliştirilen gradyan artırma temelli ağaç algoritması çerçevesinde uygulanmıştır. Bu modeller doğrudan zaman serisi modeli olmadığından, zaman bilgisinin modele aktarılması amacıyla gecikmeli değişkenlerden oluşan bir özellik seti oluşturulmuştur. Hedef değişken t dönemindeki aylık TÜFE enflasyonudur. Açıklayıcı özellikler ise $t-1$, $t-2$ ve $t-3$ dönemlerindeki enflasyon ve makroekonomik değişken değerlerinden oluşmaktadır. Bu yapı aşağıdaki genel tahmin fonksiyonu ile ifade edilebilir:

$$y_t = f(y_{t-1}, y_{t-2}, y_{t-3}, X_{t-1}, X_{t-2}, X_{t-3}) + u_t$$

Burada $f(\cdot)$, Random Forest veya XGBoost algoritması tarafından öğrenilen doğrusal olmayan tahmin fonksiyonunu; X_t ise Yİ-ÜFE, USD/TL, faiz oranı, sanayi üretimi ve Brent petrol değişkenlerinden oluşan açıklayıcı değişkenler setini göstermektedir. Bu yapı, makine öğrenmesi algoritmalarının yalnızca geçmişte gözlemlenmiş bilgilerden yararlanarak tahmin üretmesini sağlamak ve zaman serisi yapısına uygun bir modelleme çerçevesi sunmaktadır. Random Forest ve XGBoost gibi ağaç tabanlı yöntemlerin enflasyon öngörüsünde kullanılabilirliği, literatürde özellikle doğrusal olmayan ilişkileri ve değişken etkileşimlerini yakalama kapasitesiyle ilişkilendirilmektedir (Medeiros vd., 2021; Araujo ve Gaglianone, 2023; Aras ve Lisboa, 2022).

Random Forest modelinde 500 ağaç kullanılmış, maksimum derinlik 4 ve minimum yaprak gözlem sayısı 2 olarak belirlenmiştir. XGBoost modelinde ise 80 tahminci ve maksimum derinlik 2 kullanılmıştır. Hiperparametreler, küçük/orta ölçekli aylık veri setinde aşırı öğrenme riskini sınırlamak ve test dönemine genellenebilir tahminler üretmek amacıyla görece sade model yapıları tercih edilerek belirlenmiştir. Bu nedenle ağaç derinlikleri sınırlı tutulmuş, model karmaşıklığını artırabilecek daha esnek ayarlar kullanılmamıştır. Daha kapsamlı hiperparametre optimizasyonu ise çalışmanın sınırlılıkları arasında değerlendirilmiştir.

Modelleme öncesinde serilerin durağanlık özellikleri Genişletilmiş Dickey-Fuller (ADF) birim kök testiyle incelenmiştir (Dickey ve Fuller, 1979). ADF testi, değişken dönüşümlerinin zaman serisi modellemesi açısından uygunluğunu değerlendirmek ve analizde kullanılan serilerin durağanlık özelliklerini belirlemek amacıyla uygulanmıştır. Bununla birlikte, çalışmanın temel amacı katsayı yorumu veya yapısal ilişki tahmini değil, kısa dönemli örneklem dışı tahmin performansının karşılaştırılmasıdır. Bu nedenle nihai model değerlendirmesi durağanlık testlerinden ziyade test dönemi tahmin hatalarına dayandırılmıştır.

Eğitim-test ayrımı zaman serisi yapısı korunarak yapılmıştır. Modelleme veri setinde 2014:05–2024:04 dönemi başlangıç eğitim dönemi, 2024:05–2026:04 dönemi ise test dönemi olarak belirlenmiştir. Test dönemi 24 aylık bir örneklem dışı tahmin aralığını kapsamaktadır. Zaman serisi verilerinde rastgele eğitim-test ayrımı geleceğe ait bilgilerin eğitim setine dahil edilmesine yol açabileceğinden, bu çalışmada rastgele ayrım yapılmamıştır. Bunun yerine genişleyen pencere yaklaşımı kullanılarak bir adım ileri tahminler üretilmiştir. Zaman serisi tahminlerinde bu yaklaşım rolling-origin evaluation, recursive window veya expanding window olarak adlandırılmakta ve özellikle gözlem sırasının korunması gereken tahmin problemlerinde önerilmektedir (Tashman, 2000; Bergmeir ve Benítez, 2012; Rodríguez-Vargas, 2020; Boaretto ve Medeiros, 2023).

Genişleyen pencere yaklaşımında ilk test ayı olan 2024:05 için model 2014:05–2024:04 dönemi verileriyle eğitilmiş ve 2024:05 enflasyonu tahmin edilmiştir. Sonraki adımda 2024:05 gözlemi eğitim setine eklenmiş, model 2014:05–2024:05 dönemiyle yeniden tahmin edilmiş ve 2024:06 enflasyonu öngörülmüştür. Bu süreç test döneminin sonuna kadar aynı şekilde sürdürülmüştür. Böylece her tahmin adımında yalnızca ilgili

dönemden önceki bilgiler kullanılmış ve gerçek zamanlı tahmin mantığına yakın bir örneklem dışı değerlendirme yapılmıştır.

Model performansları MAE, RMSE ve MAPE ölçütleriyle değerlendirilmiştir. Bu ölçütler aşağıdaki şekilde hesaplanmıştır:

$$MAE = \frac{1}{n} \sum_{t=1}^n |y_t - \hat{y}_t|$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{t=1}^n (y_t - \hat{y}_t)^2}$$

$$MAPE = \frac{100}{n} \sum_{t=1}^n \left| \frac{y_t - \hat{y}_t}{y_t} \right|$$

Burada y_t gerçekleşen aylık enflasyon oranını, $\hat{y}_t$ model tarafından tahmin edilen enflasyon oranını, n ise test dönemindeki gözlem sayısını göstermektedir. MAE, tahmin hatalarının mutlak değerlerinin ortalamasını gösterdiği için modelin ortalama sapmasını yorumlamada kullanılmıştır. RMSE, büyük tahmin hatalarını daha fazla cezalandırdığı için özellikle yüksek oynaklık içeren dönemlerde model performansına daha duyarlı bir ölçüt sunmaktadır. MAPE ise tahmin hatasını gerçekleşen değere oranlayarak yüzde cinsinden ifade etmektedir. Bununla birlikte, gerçekleşen enflasyon oranının düşük olduğu aylarda MAPE değerlerinin görece yükselebileceği dikkate alınmış ve sonuçlar MAE ile RMSE ölçütleriyle birlikte değerlendirilmiştir.

Yöntemsel tasarımın temel amacı, farklı model sınıflarını adil ve karşılaştırılabilir bir tahmin çerçevesinde değerlendirmektir. Modellerin tamamı aynı veri seti, aynı test dönemi ve aynı hata ölçütleri üzerinden karşılaştırılmıştır. Böylece performans farklılıklarının veri seti, tahmin dönemi veya değerlendirme ölçütü farklılığından değil, model yapılarından kaynaklanması amaçlanmıştır. Çalışmanın bu kurgusu, klasik zaman serisi modelleri ile makine öğrenmesi algoritmalarının Türkiye’de aylık enflasyon öngörüsündeki performanslarını yöntemsel olarak karşılaştırmaya elverişli bir yapı sunmaktadır.

6. BULGULAR

Model tahminlerine geçmeden önce, analizde kullanılan dönüştürülmüş serilerin durağanlık özellikleri ADF birim kök testiyle incelenmiştir. Test sonuçları Tablo 4’te sunulmaktadır.

Tablo 4: ADF Birim Kök Testi Sonuçları

Değişken	ADF istatistiği	p-değeri	Gecikme	N
TÜFE enflasyonu	-2,681*	0,077	6	147
Yİ-ÜFE değişimi	-3,689***	0,004	2	147
USD/TL değişimi	-8,720***	0,000	1	147
Faiz oranı değişimi	-4,493***	0,000	9	147
Sanayi üretimi değişimi	-8,425***	0,000	3	147
Brent petrol değişimi	-7,504***	0,000	2	147

Not: ADF testinin sıfır hipotezi serinin birim kök içerdiği, diğer bir ifadeyle durağan olmadığı yönündedir. ***, ** ve * sırasıyla %1, %5 ve %10 anlamlılık düzeylerinde sıfır hipotezinin reddedildiğini göstermektedir. Testler, analizde kullanılan dönüştürülmüş seriler için uygulanmıştır.

Tablo 4’e göre analizde kullanılan dönüştürülmüş serilerin büyük bölümü %1 anlamlılık düzeyinde durağan niteliktedir. Yİ-ÜFE değişimi, USD/TL değişimi, faiz oranı değişimi, sanayi üretimi değişimi ve Brent petrol değişimi serileri birim kök içermemekte ve $I(0)$ olarak değerlendirilmektedir. TÜFE enflasyonu serisinin p-değeri 0,077 olarak hesaplanmış olup, seri %10 anlamlılık düzeyinde durağanlık göstermektedir. Bu nedenle TÜFE enflasyonu serisi de analizde kullanılan dönüşüm biçimiyle sınırda olmakla birlikte $I(0)$ kabul edilmiştir. Çalışmanın temel amacı yapısal katsayı tahmini değil, kısa dönemli örneklem dışı tahmin performansının karşılaştırılması olduğundan, durağanlık bulguları ön analiz olarak değerlendirilmiş; nihai model karşılaştırması test dönemi tahmin hatalarına dayandırılmıştır.

Klasik zaman serisi modelleri ve makine öğrenmesi algoritmalarının 2024:05–2026:04 test dönemindeki tahmin performansları Tablo 5’te verilmiştir. ARIMA modeli için Akaike Bilgi Kriteri’ne göre seçilen yapı ARIMA(3,1,3) olmuştur. SARIMAX modeli ise SARIMAX(2,1,3) yapısına dışsal değişkenlerin eklenmesiyle tahmin edilmiştir. Random Forest modeli, gecikmeli değişkenlerden oluşan özellik seti

ÖZDEMİR GÜLER, Zümre - Enflasyon Öngörüsünde Klasik Zaman Serisi ve Makine Öğrenmesi Modellerinin Performansı (The Performance of Classical Time Series and Machine Learning Models in Inflation Forecasting in Türkiye) üzerinde 500 ağaçlı, maksimum derinliği 4 olan ve minimum yaprak gözlem sayısı 2 olarak belirlenen sınırlı derinlikli bir yapı ile kurulmuştur. XGBoost modelinde ise 80 tahminci ve maksimum derinlik 2 kullanılmıştır.

Tablo 5: Model Performanslarının Karşılaştırılması

Model	MAE	RMSE	MAPE (%)
ARIMA	0,915	1,140	43,095
SARIMAX	0,930	1,153	46,009
Random Forest	1,016	1,405	48,425
XGBoost	1,024	1,374	49,837


Model performansları incelendiğinde, 2024:05–2026:04 test dönemi özelinde en düşük MAE, RMSE ve MAPE değerlerinin ARIMA modelinde elde edildiği görülmektedir. ARIMA modelinin MAE değeri 0,915, RMSE değeri 1,140 ve MAPE değeri %43,095'tir. SARIMAX modeli ARIMA'ya oldukça yakın sonuçlar üretmiş; MAE değeri 0,930, RMSE değeri 1,153 ve MAPE değeri %46,009 olarak hesaplanmıştır. Random Forest modelinde MAE 1,016, RMSE 1,405 ve MAPE %48,425; XGBoost modelinde ise MAE 1,024, RMSE 1,374 ve MAPE %49,837 olarak bulunmuştur. Bu sıralama, incelenen veri seti ve test dönemi için klasik zaman serisi modellerinin makine öğrenmesi algoritmalarına kıyasla daha düşük tahmin hatası ürettiğini göstermektedir. Bu performans sıralaması, kullanılan değişken seti ve 2024:05–2026:04 test dönemiyle sınırlı olup, farklı örneklem dönemleri, tahmin ufukları veya daha geniş özellik setleri altında değişebilir.

İncelenen veri seti ve test dönemi özelinde en düşük hata değerlerinin ARIMA modelinden elde edilmesi, aylık TÜFE enflasyonunun kısa vadede kendi geçmiş değerlerinde güçlü bilgi içerdiğini düşündürmektedir. Enflasyon serilerinde fiyatlama davranışının gecikmeli yapısı, sözleşmeler, beklentiler, maliyet aktarımı ve fiyat ayarlama davranışı nedeniyle belirli bir süreklilik görülebilir. ARIMA modeli bu sürekliliği doğrudan serinin kendi geçmiş değerleri üzerinden yakalamaktadır. Modelin tek değişkenli ve görece sade yapısına rağmen güçlü performans göstermesi, küçük/orta ölçekli aylık veri setlerinde parametrik zaman serisi modellerinin hâlâ önemli bir benchmark niteliği taşıdığını ortaya koymaktadır. Bu sonuç, Türkiye için Akbulut (2022) ve Gayaker (2024) tarafından vurgulanan klasik model performansı bulgularıyla uyumludur.

SARIMAX modelinin ARIMA'ya yakın ancak bir miktar daha yüksek hata üretmesi dikkat çekicidir. Teorik olarak dışsal değişkenlerin modele eklenmesi, enflasyonun maliyet, kur, faiz, reel aktivite ve petrol fiyatı kanallarından gelen bilgileri içermesi nedeniyle tahmin performansını artırabilir. Ancak elde edilen bulgular, dışsal değişkenlerin modele dahil edilmesinin bu veri seti ve test dönemi için tahmin hatasını azaltmadığını göstermektedir. Bu durum birkaç nedenle açıklanabilir. İlk olarak, dışsal değişkenler enflasyonla ilişkili olmakla birlikte, kısa dönemli bir adım ileri tahminlerde enflasyonun kendi geçmiş değerleri kadar güçlü ve kararlı bilgi taşımayabilir. İkinci olarak, dışsal değişkenlerin etkisi zaman içinde değişebilir; kur veya üretici fiyatı geçişkenliği bazı dönemlerde güçlü, bazı dönemlerde zayıf olabilir. Üçüncü olarak, ek değişkenler model karmaşıklığını artırarak kısa test döneminde tahmin belirsizliğini yükseltebilir.

Gerçekleşen enflasyon değerleri ile modeller tarafından üretilen tahminlerin test dönemi boyunca izlediği seyir Şekil 1'de sunulmaktadır. Şekil, modellerin genel olarak enflasyonun ana eğilimini yakalamaya çalıştığını, ancak ani yükseliş ve düşüş dönemlerinde tahmin hatalarının belirginleştiğini göstermektedir.

Şekil 1: Test Dönemi Gerçek ve Tahmin Edilen Enflasyon Değerleri



Şekil 1 incelendiğinde, ARIMA ve SARIMAX modellerinin özellikle bazı aylarda gerçekleşen enflasyon değerlerine daha yakın tahminler ürettiği görülmektedir. Buna karşılık Random Forest ve XGBoost modelleri, bazı dönemlerde gerçekleşen değerlerdeki ani sıçramaları daha düşük düzeyde tahmin etmiş ya da enflasyondaki düşüşleri sınırlı biçimde yakalayabilmiştir. Bu durum, ağaç tabanlı makine öğrenmesi modellerinin eğitim döneminde öğrendiği örüntüleri yüksek oynaklık içeren test dönemine taşımakta zorlanabileceğini düşündürmektedir.

Test dönemine ilişkin gerçekleşen ve tahmin edilen aylık enflasyon değerleri Tablo 6’da ayrıntılı olarak verilmiştir. Bu tablo, model performanslarının yalnızca toplam hata ölçütleriyle değil, her bir test ayı düzeyinde de izlenebilmesine olanak sağlamaktadır.

Tablo 6: Test Dönemi Gerçek ve Tahmin Edilen Enflasyon Değerleri

Tarih	Gerçek	ARIMA	SARIMAX	RF	XGBoost
2024:05	3,313	3,007	3,724	3,306	3,390
2024:06	1,627	3,160	3,560	3,233	2,358
2024:07	3,175	3,169	3,157	1,806	2,065
2024:08	2,444	3,088	3,298	3,270	3,890
2024:09	2,925	2,491	2,710	1,830	1,689
2024:10	2,839	3,892	3,625	3,045	3,683
2024:11	2,219	2,716	2,558	2,197	1,939
2024:12	1,023	2,331	2,365	1,883	1,844
2025:01	4,910	2,558	2,802	1,038	1,135
2025:02	2,248	4,199	3,744	2,440	2,526
2025:03	2,430	1,969	2,601	1,828	2,093
2025:04	2,953	3,508	3,387	2,675	3,595
2025:05	1,517	2,973	3,067	2,670	2,584
2025:06	1,364	1,425	2,434	2,268	2,140
2025:07	2,038	2,872	3,162	2,051	1,898
2025:08	2,015	2,265	2,402	1,640	1,609
2025:09	3,183	1,658	1,936	1,540	1,812
2025:10	2,518	3,954	3,061	2,212	1,946
2025:11	0,861	2,283	2,148	2,137	2,142
2025:12	0,884	1,000	1,335	2,752	3,331
2026:01	4,723	2,574	2,205	1,232	1,485
2026:02	2,922	3,680	2,580	2,009	2,182
2026:03	1,924	1,936	2,001	2,224	1,862
2026:04	4,097	3,251	2,476	2,892	3,194

Tablo 6’daki değerler, modellerin bazı aylarda oldukça yakın tahminler üretebildiğini, bazı aylarda ise gerçekleşen enflasyon oranından belirgin biçimde saptığını göstermektedir. Örneğin 2025:01 ve 2026:01 gibi

enflasyonun yüksek gerçekleştiği aylarda makine öğrenmesi modellerinin gerçekleşen değerin altında tahminler ürettiği görülmektedir. Benzer şekilde, enflasyonun düşük gerçekleştiği bazı aylarda modellerin daha yüksek tahminler üretmesi, kısa dönemli enflasyon hareketlerindeki ani dalgalanmaların tüm model sınıfları için zorlayıcı olduğunu göstermektedir. Bu bulgu, Türkiye’de aylık enflasyon öngörüsünün yalnızca model seçimine değil, aynı zamanda test dönemindeki makroekonomik oynaklık, politika değişimleri ve beklenti hareketlerine de duyarlı olduğunu ortaya koymaktadır.

Random Forest ve XGBoost modellerinin klasik modellere göre daha yüksek hata üretmesi, makine öğrenmesi algoritmalarının her veri yapısında otomatik üstünlük sağlamadığını göstermektedir. Bu modeller genellikle daha büyük veri setlerinde ve daha geniş özellik uzaylarında güçlü performans göstermektedir. Mevcut çalışmada aylık frekans nedeniyle gözlem sayısı sınırlıdır. Modelleme dönemi 2014:05–2026:04 olsa da test dönemi 24 aydan oluşmakta, eğitim seti ise aylık makroekonomik veri açısından orta büyüklüktedir. Ağaç tabanlı algoritmaların karmaşık örüntüleri güvenilir biçimde öğrenebilmesi için daha fazla gözlem, daha zengin değişken seti veya daha ayrıştırılmış fiyat bileşenleri gerekebilir.

Test döneminin özellikleri de sonuçları etkilemiş olabilir. 2024:05–2026:04 dönemi Türkiye ekonomisi açısından enflasyonun yüksek seviyelerde seyrettiği, politika ayarlamalarının ve beklenti değişimlerinin önem taşıdığı bir dönemi temsil etmektedir. Bu tür dönemlerde makine öğrenmesi modelleri eğitim döneminde öğrendikleri örüntüleri test dönemine taşımakta zorlanabilir. Özellikle rejim değişimi, politika tepkileri veya kur geçişkenliğinde dönemsel farklılaşma söz konusu olduğunda, geçmiş örüntüler geleceği açıklamada sınırlı kalabilir. ARIMA modelinin genişleyen pencereyle her adımda yeniden tahmin edilmesi, enflasyonun yakın geçmiş dinamiklerine daha hızlı uyum sağlamasına yardımcı olmuş olabilir.

Bununla birlikte, makine öğrenmesi modellerinin sonuçları tamamen olumsuz yorumlanmamalıdır. Random Forest ve XGBoost modellerinden elde edilen değişken önemleri, enflasyon öngörüsünde hangi göstergelerin bilgi taşıdığına ilişkin önemli ipuçları sunmaktadır. Random Forest modeline ilişkin ilk sekiz değişken önemi Tablo 7’de, XGBoost modeline ilişkin ilk sekiz değişken önemi ise Tablo 8’de verilmiştir.

Tablo 7: Random Forest Değişken Önemleri - İlk 8 Değişken

Değişken	Önem
fx_lag1	0,353
inf_lag1	0,208
ppi_lag1	0,191
inf_lag3	0,080
inf_lag2	0,044
ppi_lag3	0,024
ipi_lag3	0,016
int_lag3	0,011

Not: Değişken adlarında yer alan lag1, lag2 ve lag3 ifadeleri sırasıyla ilgili değişkenin 1, 2 ve 3 dönem gecikmeli değerlerini göstermektedir. Değişken kodları Tablo 2’de tanımlanmıştır.

Tablo 7’ye göre Random Forest modelinde USD/TL değişiminin bir dönem gecikmesi en yüksek öneme sahiptir. Bu değişkeni TÜFE enflasyonunun bir dönem gecikmesi ve Yİ-ÜFE değişiminin bir dönem gecikmesi izlemektedir.

Tablo 8: XGBoost Değişken Önemleri - İlk 8 Değişken

Değişken	Önem
inf_lag1	0,184
ppi_lag1	0,157
fx_lag1	0,137
inf_lag3	0,068
inf_lag2	0,068
brent_lag3	0,062
ipi_lag3	0,060
ipi_lag2	0,051

Not: Değişken adlarında yer alan lag1, lag2 ve lag3 ifadeleri sırasıyla ilgili değişkenin 1, 2 ve 3 dönem gecikmeli değerlerini göstermektedir. Değişken kodları Tablo 2’de tanımlanmıştır.

Tablo 8’de sunulan XGBoost sonuçlarına göre ise ilk sırada TÜFE enflasyonunun bir dönem gecikmesi yer almakta, ardından Yİ-ÜFE değişiminin ve USD/TL değişiminin bir dönem gecikmeleri gelmektedir. Her iki modelde de ilk sıralarda geçmiş enflasyon, kur değişimi ve üretici fiyatları yer almaktadır. Bu bulgu, Türkiye’de kısa dönemli enflasyon öngörüsünde geçmiş enflasyon, kur hareketleri ve üretici fiyatlarının temel bilgi kaynakları olduğunu göstermektedir.

Değişken önemleri iktisadi açıdan da anlamlıdır. USD/TL kurundaki artışlar, ithal girdi maliyetleri ve fiyatlama beklentileri aracılığıyla tüketici fiyatlarına yansiyabilir. Türkiye’de üretim yapısının ithal ara malı bağımlılığı ve döviz kuru hareketlerinin beklentiler üzerindeki etkisi dikkate alındığında, kur değişiminin enflasyon tahmininde öne çıkması beklenen bir bulgudur. Yİ-ÜFE değişiminin yüksek önem taşıması ise üretici fiyatlarından tüketici fiyatlarına maliyet geçişinin varlığına işaret etmektedir. Özellikle enerji, hammadde ve ara malı maliyetlerindeki artışların önce üretici fiyatlarına, ardından belirli gecikmelerle tüketici fiyatlarına yansması mümkündür. Geçmiş TÜFE enflasyonunun öne çıkması ise enflasyon ataleti ve gecikmeli uyarlanma davranışıyla ilişkilendirilebilir.

Brent petrol, sanayi üretimi ve faiz oranı değişkenlerinin değişken önemlerinde daha alt sıralarda yer alması, bu değişkenlerin tahmin gücünün tamamen zayıf olduğu anlamına gelmemelidir. Söz konusu değişkenlerin etkisi dolaylı, gecikmeli veya dönemsel olabilir. Petrol fiyatı artışları kur hareketleri ve Yİ-ÜFE üzerinden tüketici fiyatlarına yansıyor olabilir. Sanayi üretimindeki değişimler talep koşullarını temsil etmekle birlikte aylık enflasyonda doğrudan ve kısa vadede daha sınırlı bir etki gösterebilir. Faiz oranı değişimleri ise para politikası aktarım mekanizması yoluyla daha uzun gecikmelerle fiyatlara yansiyabilir. Bu nedenle değişken önemleri, yalnızca mevcut model ve gecikme yapısı içinde yorumlanmalıdır.

Bulgular literatürle karşılaştırıldığında, model performansının veri yapısı, tahmin ufkı, dönem özellikleri ve değişken setine bağlı olduğu görülmektedir. Medeiros vd. (2021), ABD için Random Forest’ın veri-zengin ortamda güçlü performans gösterdiğini belirtirken, Araujo ve Gaglianone (2023) Brezilya için tek bir evrensel en iyi model olmadığını göstermiştir. Liu vd. (2024), Japonya örneğinde LASSO’nun pandemi sonrası dönemde başarılı olduğunu ortaya koyarak en karmaşık modelin her zaman en iyi sonucu vermeyebileceğini göstermektedir. Türkiye özelinde Akbulut (2022) ve Gayaker (2024) ise klasik zaman serisi modellerinin belirli koşullarda güçlü performans gösterebildiğini belirtmektedir. Mevcut çalışmada ARIMA’nın Random Forest ve XGBoost’tan daha düşük hata üretmesi, bu bağlamsallık vurgusunu desteklemektedir.

Genel olarak bulgular, kısa dönemli enflasyon tahmininde model karmaşıklığının tek başına başarı getirmedikçe göstermektedir. Makine öğrenmesi algoritmaları doğrusal olmayan ilişkileri yakalama kapasitesine sahip olsa da bu kapasitenin tahmin performansına dönüşebilmesi için yeterli gözlem sayısı, uygun gecikme yapısı, zengin değişken seti ve sağlam hiperparametre ayarlaması gerekmektedir. Ayrıca enflasyonun kısa dönemli hareketlerinde geçmiş enflasyonun bilgi içeriği yüksek olduğunda, tek değişkenli klasik modeller güçlü sonuçlar verebilir. Dolayısıyla model seçimi yapılırken yalnızca algoritmanın güncelliği veya karmaşıklığı değil, veri setinin özellikleri ve tahmin amacının niteliği dikkate alınmalıdır.

SONUÇ VE TARTIŞMA

Türkiye’de aylık TÜFE enflasyonunun kısa dönemli öngörüsünde klasik zaman serisi modelleri ile makine öğrenmesi algoritmalarının tahmin performanslarının karşılaştırıldığı analizler, model başarısının yalnızca yöntemin güncelliği veya karmaşıklığıyla açıklanamayacağını göstermektedir. 2014:05–2026:04 dönemini kapsayan modelleme veri seti üzerinden 2024:05–2026:04 test dönemi için yapılan örneklem dışı tahminlerde ARIMA, SARIMAX, Random Forest ve XGBoost modelleri aynı veri seti, aynı test dönemi ve aynı hata ölçütleri altında değerlendirilmiştir. Elde edilen bulgular, incelenen dönem ve değişken seti için en düşük tahmin hatasının ARIMA modelinde ortaya çıktığını göstermiştir.

Model performansları MAE, RMSE ve MAPE ölçütleriyle karşılaştırıldığında ARIMA modelinin MAE değeri 0,915, RMSE değeri 1,140 ve MAPE değeri %43,095 olarak hesaplanmıştır. SARIMAX modeli ARIMA’ya oldukça yakın bir performans sergilemiş; ancak dışsal değişkenlerin eklenmesi tahmin hatasını azaltmamıştır. Random Forest ve XGBoost modelleri ise klasik zaman serisi modellerine göre daha yüksek hata değerleri üretmiştir. Sıralama genel olarak ARIMA, SARIMAX, Random Forest ve XGBoost biçiminde oluşmuştur. Böylece Türkiye’de aylık enflasyonun kısa dönemli öngörüsünde, seçilen veri seti ve test

dönemi özelinde klasik zaman serisi modellerinin makine öğrenmesi algoritmalarına göre daha düşük tahmin hatası ürettiği görülmüştür.

İncelenen veri seti ve test dönemi özelinde ARIMA modelinin en düşük hata değerlerini üretmesi, aylık TÜFE enflasyonunun kısa vadede kendi geçmiş değerlerinden güçlü biçimde etkilendiğine işaret etmektedir. Enflasyon serilerinde fiyat ayarlama davranışı, beklentiler, maliyet aktarımı, sözleşme yapıları ve gecikmeli uyarlanma mekanizmaları nedeniyle belirli bir süreklilik gözlenebilir. ARIMA modeli, enflasyonun bu içsel zaman serisi dinamiğini doğrudan dikkate aldığı için kısa dönemli tahminlerde güçlü bir karşılaştırma modeli niteliği taşımaktadır. Tek değişkenli ve görece sade yapısına rağmen ARIMA'nın başarılı olması, özellikle küçük ve orta ölçekli aylık makroekonomik veri setlerinde klasik modellerin hâlâ oldukça rekabetçi olduğunu göstermektedir.

SARIMAX modelinin ARIMA'ya yakın ancak bir miktar daha yüksek hata üretmesi, dışsal değişkenlerin modele dahil edilmesinin tahmin performansını her durumda artırmadığını ortaya koymaktadır. Yİ-ÜFE, USD/TL kuru, faiz oranı, sanayi üretim endeksi ve Brent petrol fiyatı teorik olarak enflasyon dinamikleriyle ilişkili değişkenlerdir. Buna karşın kısa dönemli bir adım ileri tahminlerde bu göstergelerin bilgi içeriği, enflasyonun kendi geçmiş değerleri kadar istikrarlı olmayabilir. Kur geçişkenliği, üretici fiyatlarından tüketici fiyatlarına aktarım, faiz oranı etkisi ve petrol fiyatı kanalı dönemden döneme farklılaşabilmektedir. Dışsal değişkenlerin modele eklenmesi, bilgi setini genişletirken aynı zamanda model karmaşıklığını artırmakta ve kısa test dönemlerinde tahmin belirsizliğini yükseltebilmektedir.

Random Forest ve XGBoost modellerinin daha yüksek hata üretmesi, makine öğrenmesi algoritmalarının enflasyon öngörüsünde koşulsuz üstünlük sağlamadığını göstermesi bakımından önemlidir. Ağaç tabanlı algoritmalar doğrusal olmayan ilişkileri ve değişkenler arası etkileşimleri yakalama kapasitesine sahip olsa da bu kapasitenin başarılı tahmin performansına dönüşebilmesi için yeterli gözlem sayısı, uygun özellik seti, etkili hiperparametre ayarlaması ve istikrarlı bir veri üretim süreci gerekmektedir. Aylık frekansta çalışılması nedeniyle gözlem sayısının sınırlı kalması, test döneminin yalnızca 24 aydan oluşması ve Türkiye'de enflasyon dinamiklerinin yüksek oynaklık içermesi, makine öğrenmesi modellerinin performansını sınırlamış olabilir.

Test dönemi açısından bakıldığında 2024:05–2026:04 aralığı, Türkiye ekonomisinde yüksek enflasyon, politika ayarlamaları, kur hareketleri ve beklenti değişimlerinin etkili olduğu bir döneme karşılık gelmektedir. Böyle dönemlerde geçmiş örüntülere dayalı algoritmaların test dönemindeki yeni dinamikleri yakalaması zorlaşabilir. Rejim değişimi, para politikası tepkileri, fiyatlama davranışındaki kırılmalar veya kur geçişkenliğinin dönemsel olarak farklılaşması, makine öğrenmesi modellerinin eğitim döneminde öğrendiği ilişkileri test dönemine taşımakta zorlanmasına neden olabilir. ARIMA modelinin genişleyen pencere yaklaşımıyla her adımda yeniden tahmin edilmesi ise yakın geçmiş enflasyon dinamiklerine daha hızlı uyum sağlamasına katkıda bulunmuş olabilir.

Makine öğrenmesi modellerinin tahmin hatası bakımından klasik modellerin gerisinde kalması, bu modellerin tamamen işlevsiz olduğu anlamına gelmemektedir. Random Forest ve XGBoost modellerinden elde edilen değişken önemleri, Türkiye'de kısa dönemli enflasyon öngörüsünde hangi göstergelerin bilgi taşıdığına ilişkin önemli ipuçları sunmaktadır. Random Forest modelinde USD/TL değişiminin bir dönem gecikmesi en yüksek öneme sahipken, bunu TÜFE enflasyonunun ve Yİ-ÜFE değişiminin bir dönem gecikmeleri izlemiştir. XGBoost modelinde ise ilk sırada TÜFE enflasyonunun bir dönem gecikmesi yer almış, ardından Yİ-ÜFE ve USD/TL değişiminin gecikmeli değerleri gelmiştir. Her iki modelde de geçmiş enflasyon, kur değişimi ve üretici fiyatları ilk sıralarda yer almıştır.

Değişken önemlerinden elde edilen bulgular iktisadi açıdan anlamlıdır. USD/TL kurundaki değişimler, ithal girdi maliyetleri ve fiyatlama beklentileri aracılığıyla tüketici fiyatlarına yansiyabilmektedir. Türkiye ekonomisinde üretim yapısının ithal ara malı bağımlılığı ve döviz kuru hareketlerinin beklentiler üzerindeki etkisi dikkate alındığında, kur değişiminin kısa dönemli enflasyon öngörüsünde öne çıkması beklenen bir sonuçtur. Yİ-ÜFE değişiminin yüksek önem taşıması, üretici fiyatlarından tüketici fiyatlarına maliyet geçişinin varlığına işaret etmektedir. Geçmiş TÜFE enflasyonunun öne çıkması ise enflasyon ataleti ve gecikmeli uyarlanma davranışıyla ilişkilendirilebilir.

Brent petrol, sanayi üretimi ve faiz oranı değişkenlerinin değişken önemlerinde daha alt sıralarda yer alması, ilgili göstergelerin enflasyon üzerinde etkisiz olduğu biçiminde yorumlanmamalıdır. Petrol fiyatlarının etkisi kur ve üretici fiyatları üzerinden dolaylı biçimde ortaya çıkabilir. Sanayi üretimi reel ekonomik aktiviteyi temsil etmekle birlikte aylık enflasyon üzerinde daha sınırlı veya dönemsel bir etkiye sahip olabilir. Faiz

oranı değişimleri ise para politikası aktarım mekanizması yoluyla fiyatlara daha uzun gecikmelerle yansiyabilir. Dolayısıyla değişken önemleri, yalnızca kullanılan model, veri seti ve gecikme yapısı çerçevesinde değerlendirilmelidir.

Literatürle karşılaştırıldığında elde edilen sonuçlar, enflasyon öngörüsünde model performansının ülke, dönem, tahmin ufku, veri büyüklüğü ve değişken setine duyarlı olduğu yönündeki bulguları desteklemektedir. Medeiros vd. (2021), ABD için veri-zengin ortamda Random Forest modelinin güçlü performans gösterdiğini ortaya koyarken, Araujo ve Gaglianone (2023), Brezilya için tek bir evrensel en iyi model bulunmadığını göstermiştir. Liu vd. (2024), Japonya örneğinde pandemi sonrası dönemde LASSO modelinin başarılı sonuç verdiğini belirterek en karmaşık modelin her zaman en iyi performansı sunmayabileceğini ortaya koymaktadır. Türkiye özelinde Akbulut (2022) ve Gayaker (2024) ise klasik zaman serisi modellerinin belirli veri ve dönem koşullarında güçlü sonuçlar verebildiğini vurgulamaktadır. Mevcut analizde ARIMA modelinin Random Forest ve XGBoost algoritmalarından daha düşük hata üretmesi, bu bağlamsallık vurgusuyla uyumludur.

Çalışmanın temel katkısı, Türkiye’de aylık TÜFE enflasyonunun kısa dönemli öngörüsünde klasik zaman serisi modelleri ile makine öğrenmesi algoritmalarını aynı veri seti, aynı test dönemi ve aynı hata ölçütleri altında karşılaştırmasıdır. Böylece model performansındaki farklılıkların veri seti ya da değerlendirme döneminden değil, model yapısından kaynaklanmasına yönelik daha adil bir karşılaştırma zemini oluşturulmuştur. Genişleyen pencere yaklaşımıyla her tahmin adımında yalnızca geçmiş bilgiler kullanılmış, rastgele eğitim-test ayırımından kaynaklanabilecek veri sızıntısı önlenmiş ve gerçek zamanlı tahmin mantığına daha yakın bir değerlendirme yapılmıştır.

Elde edilen bulgular, Türkiye’de kısa dönemli enflasyon öngörüsünde model seçiminde algoritmanın karmaşıklığından çok veri yapısına ve tahmin amacına uygunluğun belirleyici olduğunu göstermektedir. Makine öğrenmesi algoritmaları doğrusal olmayan ilişkileri yakalama potansiyeline sahip olsa da sınırlı aylık gözlem sayısı ve yüksek oynaklık içeren test dönemlerinde klasik zaman serisi modelleri daha istikrarlı sonuçlar verebilmektedir. Kısa vadeli tahminlerde geçmiş enflasyon dinamiklerinin yüksek bilgi içeriği taşıdığı durumlarda, ARIMA gibi sade modeller güçlü bir benchmark olmayı sürdürmektedir.

Bulguların politika ve uygulama açısından anlamı, enflasyon öngörüsünde tek bir model ailesine bağlı kalınmaması gerektiğidir. Kısa dönemli tahminlerde klasik zaman serisi modelleri güçlü bir başlangıç noktası sunarken, makine öğrenmesi algoritmaları değişken önemleri, doğrusal olmayan ilişki arayışı ve alternatif senaryo üretimi açısından tamamlayıcı araçlar olarak değerlendirilebilir. Özellikle kur değişimi, üretici fiyatları ve geçmiş enflasyonun öne çıkması, Türkiye’de kısa vadeli fiyat hareketlerinin izlenmesinde bu göstergelerin önemini ortaya koymaktadır. Buna karşılık faiz oranı, petrol fiyatı ve sanayi üretimi gibi değişkenlerin etkileri daha uzun gecikmelerle veya dolaylı kanallarla ortaya çıkabileceğinden, farklı gecikme yapıları ve alternatif model kurulumlarıyla yeniden incelenmeleri yararlı olacaktır.

Çalışmanın bazı sınırlılıkları da bulunmaktadır. Veri seti aylık frekansta ve ortak eksiksiz dönemle sınırlı olduğundan gözlem sayısı makine öğrenmesi modelleri için görece düşüktür. Tahmin ufku bir adım ileri kısa dönemli öngörüyle sınırlandırılmıştır. Açıklayıcı değişken seti iktisadi gerekçesi güçlü temel makroekonomik göstergelerden oluşmakla birlikte, beklenti göstergeleri, alt enflasyon kalemleri, finansal piyasa değişkenleri, emtia alt grupları veya yüksek frekanslı göstergeler veri setine dahil edilmemiştir. Hiperparametre ayarlaması aşırı öğrenme riskini azaltacak biçimde sınırlı tutulmuş, daha kapsamlı optimizasyon stratejileri uygulanmamıştır. Bu sınırlılıklar, elde edilen sonuçların makine öğrenmesi algoritmalarının genel başarısızlığı olarak değil, kullanılan veri seti ve tahmin tasarımı özelindeki performansları olarak yorumlanmasını gerektirmektedir.

Gelecek çalışmalar açısından birkaç genişletme alanı öne çıkmaktadır. Daha uzun dönemli ve daha geniş değişken setleriyle makine öğrenmesi modellerinin performansı yeniden değerlendirilebilir. TÜFE alt kalemleri kullanılarak ayrıştırılmış enflasyon bileşenlerinden toplam enflasyona ulaşan bottom-up yaklaşımlar denenebilir. LASSO, Elastic Net, destek vektör regresyonu, yapay sinir ağları, LSTM ve model kombinasyonları gibi alternatif yöntemler karşılaştırmaya dahil edilebilir. Farklı tahmin ufukları için doğrudan çok adımlı öngörü stratejileri uygulanabilir. Ayrıca SHAP veya benzeri açıklanabilir yapay zekâ yöntemleriyle makine öğrenmesi tahminlerinin iktisadi yorumlanabilirliği güçlendirilebilir. Böylece enflasyon öngörüsünde hem tahmin doğruluğu hem de model açıklanabilirliği birlikte değerlendirilebilir.

Genel olarak analiz sonuçları, Türkiye’de aylık enflasyonun kısa dönemli öngörüsünde klasik zaman serisi modellerinin hâlâ güçlü ve güvenilir bir karşılaştırma zemini sunduğunu göstermektedir. Makine öğrenmesi

ÖZDEMİR GÜLER, Zümre - Enflasyon Öngörüsünde Klasik Zaman Serisi ve Makine Öğrenmesi Modellerinin Performansı (The Performance of Classical Time Series and Machine Learning Models in Inflation Forecasting in Türkiye) algoritmaları önemli bir potansiyel taşımakla birlikte, bu potansiyelin tahmin başarısına dönüşmesi veri setinin kapsamına, örneklem uzunluğuna, değişken çeşitliliğine, tahmin ufkuna ve dönemsel makroekonomik koşullara bağlıdır. Enflasyon öngörüsünde en uygun modelin önceden varsayılması yerine, farklı model sınıflarının aynı veri ve test koşulları altında sistematik biçimde karşılaştırılması daha sağlıklı bir yaklaşım sunmaktadır. Bu yönüyle çalışma, Türkiye’de enflasyon öngörüsü literatürüne yöntem karşılaştırması ekseninde katkı sağlamakta ve kısa dönemli tahmin çalışmalarında klasik modeller ile makine öğrenmesi algoritmalarının birlikte değerlendirilmesi gerektiğini ortaya koymaktadır.

KAYNAKÇA

- Akaike, H. (1974). A new look at the statistical model identification. *IEEE Transactions on Automatic Control*, 19(6), 716-723. <https://doi.org/10.1109/TAC.1974.1100705>
- Akbulut, H. (2022). Forecasting inflation in Turkey: A comparison of time-series and machine learning models. *Economic Journal of Emerging Markets*, 14(1), 55-71.
- Aras, S., & Lisboa, P. J. G. (2022). Explainable inflation forecasts by machine learning models. *Expert Systems with Applications*, 207, 117982. <https://doi.org/10.1016/j.eswa.2022.117982>
- Araujo, G. S., & Gaglianone, W. P. (2023). Machine learning methods for inflation forecasting in Brazil: New contenders versus classical models. *Latin American Journal of Central Banking*, 4(2), 100087. <https://doi.org/10.1016/j.latchb.2023.100087>
- Bergmeir, C., & Benítez, J. M. (2012). On the use of cross-validation for time series predictor evaluation. *Information Sciences*, 191, 192-213. <https://doi.org/10.1016/j.ins.2011.12.028>
- Boaretto, G., & Medeiros, M. C. (2023). Forecasting inflation using disaggregates and machine learning. arXiv:2308.11173.
- Box, G. E. P., Jenkins, G. M., Reinsel, G. C., & Ljung, G. M. (2015). *Time series analysis: Forecasting and control* (5th ed.). Wiley.
- Breiman, L. (2001). Random forests. *Machine Learning*, 45, 5-32. <https://doi.org/10.1023/A:1010933404324>
- Chen, T., & Guestrin, C. (2016). XGBoost: A scalable tree boosting system. In *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining* (pp. 785-794). ACM. <https://doi.org/10.1145/2939672.2939785>
- Dickey, D. A., & Fuller, W. A. (1979). Distribution of the estimators for autoregressive time series with a unit root. *Journal of the American Statistical Association*, 74(366), 427-431. <https://doi.org/10.2307/2286348>
- Gayaker, S. (2024). Türkiye’de ekonomik şoklar ve krizler bağlamında enflasyon öngörüsü: XGBoost ve ARMA yöntemlerinin karşılaştırması. *Ekonomi, Politika & Finans Araştırmaları Dergisi*, 9(4), 877-895.
- Goulet Coulombe, P. (2021). The Macroeconomy as a Random Forest. arXiv:2006.12724.
- Kohlscheen, E. (2022). What does machine learning say about the drivers of inflation? *BIS Working Papers*, No. 980.
- Liu, Y., Pan, R., & Xu, R. (2024). Mending the crystal ball: Enhanced inflation forecasts with machine learning. *IMF Working Paper* WP/24/206.
- Masini, R. P., Medeiros, M. C., & Mendes, E. F. (2021). Machine learning advances for time series forecasting. *Journal of Economic Surveys*, 37(1), 76-111. <https://doi.org/10.1111/joes.12429>
- Medeiros, M. C., Vasconcelos, G. F. R., Veiga, A., & Zilberman, E. (2021). Forecasting inflation in a data-rich environment: The benefits of machine learning methods. *Journal of Business & Economic Statistics*, 39(1), 98-119. <https://doi.org/10.1080/07350015.2019.1637745>
- Nalıcı, M. E., Söylemez, İ., & Ünlü, R. (2025). Forecasting the Consumer Price Index in Türkiye using machine learning models: A comparative analysis. *Gazi University Journal of Science*, 38(3), 1359-1372.
- Rodríguez-Vargas, A. (2020). Forecasting Costa Rican inflation with machine learning methods. *Latin American Journal of Central Banking*, 1, 100012. <https://doi.org/10.1016/j.latchb.2020.100012>
- Tashman, L. J. (2000). Out-of-sample tests of forecasting accuracy: An analysis and review. *International Journal of Forecasting*, 16(4), 437-450. [https://doi.org/10.1016/S0169-2070\(00\)00065-0](https://doi.org/10.1016/S0169-2070(00)00065-0)

EXTENDED ABSTRACT

Background

Inflation forecasting is a central issue for policymakers, firms, households and financial institutions because future price movements affect expectations, contracts, wage negotiations, budget planning and investment decisions. In economies such as Türkiye, where inflation volatility is high and exchange rate movements can quickly affect pricing behaviour, short-term forecasting becomes particularly challenging. Recent literature increasingly evaluates machine learning algorithms alongside classical econometric and time series models. However, empirical evidence does not suggest that machine learning models are unconditionally superior. Forecasting performance depends on the country context, data size, prediction horizon, model structure and the stability of macroeconomic relationships.

Purpose

This study examines the performance of classical time series and machine learning models in short-term monthly inflation forecasting in Türkiye. The main objective is not to estimate a structural inflation equation, but to compare the out-of-sample forecasting accuracy of different model families under the same data, same test period and same error metrics. The study focuses on whether the inclusion of external macroeconomic indicators and the use of nonlinear machine learning algorithms improve short-term inflation forecasts relative to a classical univariate time series benchmark.

Method

The empirical analysis uses monthly data covering the modelling period 2014:05-2026:04. The dependent variable is the monthly logarithmic inflation rate calculated from the consumer price index. Explanatory variables include producer prices, the USD/TL exchange rate, the interest rate, the industrial production index and Brent crude oil prices, representing cost pressures, exchange rate pass-through, financial conditions, real economic activity and external cost factors. ARIMA and SARIMAX models represent the classical time series approach, while Random Forest and XGBoost represent the machine learning approach. Since the data have a time series structure, the training-test split is not random. The period 2014:05-2024:04 is used as the initial training period and 2024:05-2026:04 is used as the test period. Forecasts are produced through an expanding-window one-step-ahead scheme. Model performance is evaluated using MAE, RMSE and MAPE. The machine learning feature set is constructed from one-, two- and three-period lagged values of inflation and the explanatory variables.

Findings

The empirical results show that the ARIMA model provides the lowest forecasting errors during the test period. The SARIMAX model follows ARIMA closely, but the inclusion of external macroeconomic variables does not reduce forecast errors in this setting. Random Forest and XGBoost produce higher error values than the classical time series models. This finding indicates that more complex or more flexible models do not automatically generate better inflation forecasts, especially when the sample size is limited and the test period is characterized by high volatility. Variable importance results from the machine learning models nevertheless provide useful economic insights. In both Random Forest and XGBoost, lagged inflation, exchange rate changes and producer price changes appear among the most informative predictors. This pattern is consistent with inflation persistence, exchange rate pass-through and cost-side price pressures in the Turkish economy.

Conclusion

The study concludes that classical time series models remain strong benchmarks for short-term monthly inflation forecasting in Türkiye. Machine learning algorithms have important potential, particularly for detecting nonlinear relationships and evaluating variable importance, but this potential depends on data richness, sample length, feature design, model tuning and macroeconomic stability. The results should therefore not be interpreted as a general rejection of machine learning methods. Instead, they show that model choice in inflation forecasting should be guided by out-of-sample performance rather than methodological novelty alone. Future research may extend the analysis by using disaggregated CPI components, expectation indicators, financial stress variables, alternative machine learning algorithms, model combinations and multi-step forecasting horizons. Such extensions may provide a more comprehensive assessment of when machine learning models can outperform classical time series methods in inflation forecasting for Türkiye.